

# Statistika a spolehlivost v lékařství – vzorce ke zkoušce

## 1 Vlastnosti podmíněných rozdělení

$$EY = E(E(Y|X)),$$

$$DY = D(E(Y|X)) + E(D(Y|X)).$$

## 2 Intervalové odhady parametrů **normálního** rozdělení $N(\mu, \sigma^2)$

(Uvedeny pouze symetrické oboustranné odhady.)

Odhad střední hodnoty při **známém** rozptylu  $\sigma^2$ :  $\bar{x} \pm \frac{\sigma}{\sqrt{n}} \Phi^{-1} \left( 1 - \frac{\alpha}{2} \right)$ .

Odhad střední hodnoty při **neznámém** rozptylu:  $\bar{x} \pm \frac{s_x}{\sqrt{n}} q_{t(n-1)} \left( 1 - \frac{\alpha}{2} \right)$ .

Odhad rozptylu:  $\left\langle \frac{(n-1) s_x^2}{q_{\chi^2(n-1)} \left( 1 - \frac{\alpha}{2} \right)}, \frac{(n-1) s_x^2}{q_{\chi^2(n-1)} \left( \frac{\alpha}{2} \right)} \right\rangle$ .

## 3 Testování hypotéz

**Typický tvar testu:** Testovací statistiku  $T$ , která roste s parametrem  $\vartheta$  (přesněji její realizaci  $t$ ) porovnáme s kvantily příslušného rozdělení za předpokladu  $\vartheta = c$ :

$H_0$	$H_1$	zamítáme pro	dosažená významnost
$\vartheta \leq c$	$\vartheta > c$	$t > q_T(1 - \alpha)$	$1 - F_T(t)$
$\vartheta \geq c$	$\vartheta < c$	$t < q_T(\alpha)$	$F_T(t)$
$\vartheta = c$	$\vartheta \neq c$	$t > q_T(1 - \frac{\alpha}{2})$ nebo $t < q_T(\frac{\alpha}{2})$	$2 \min(F_T(t), 1 - F_T(t))$

Test střední hodnoty normálního rozdělení při **známém** rozptylu  $\sigma^2$ :  $\frac{\bar{x} - c}{\sigma} \sqrt{n}$  testujeme na rozdělení  $N(0, 1)$ .

Test střední hodnoty normálního rozdělení při **neznámém** rozptylu:  $\frac{\bar{x} - c}{s_x} \sqrt{n}$  testujeme na rozdělení  $t(n-1)$ .

Test rozptylu normálního rozdělení:  $\frac{(n-1) s_x^2}{c}$  testujeme na rozdělení  $\chi^2(n-1)$ .

Test rovnosti rozptylů dvou normálních rozdělení (Fisherův):  $\frac{s_x^2}{s_y^2}$  testujeme na rozdělení  $F(m-1, n-1)$ .

Test rovnosti středních hodnot dvou normálních rozdělení se **známým** rozptylem  $\sigma^2$ :  $\frac{\bar{x}_m - \bar{y}_n}{\sigma \sqrt{\frac{1}{m} + \frac{1}{n}}}$  testujeme na rozdělení  $N(0, 1)$ .

Test rovnosti středních hodnot dvou normálních rozdělení se stejným **neznámým** rozptylem:  $\frac{\bar{x}_m - \bar{y}_n}{s \sqrt{\frac{1}{m} + \frac{1}{n}}}$ , kde

$s^2 = \frac{(m-1) s_x^2 + (n-1) s_y^2}{m+n-2}$ , testujeme na rozdělení  $t(m+n-2)$ .

**Párový pokus** – test rovnosti středních hodnot dvou normálních rozdělení se **známým** rozptylem  $\sigma^2$ :  $\frac{\bar{x} - \bar{y}}{\sigma} \sqrt{\frac{n}{2}}$  testujeme na rozdělení  $N(0, 1)$ .

**Párový pokus** – test rovnosti středních hodnot dvou normálních rozdělení se stejným **neznámým** rozptylem:  $\frac{\bar{\delta}}{s_\delta} \sqrt{n}$ , kde  $\delta_j = x_j - y_j$ , testujeme na rozdělení  $t(n-1)$ .

### 3.1 Testy korelace

$$r_{\mathbf{x}, \mathbf{y}} = \frac{\sum_{j=1}^n (x_j - \bar{x})(y_j - \bar{y})}{\sqrt{\left(\sum_{j=1}^n (x_j - \bar{x})^2\right) \left(\sum_{j=1}^n (y_j - \bar{y})^2\right)}} = \frac{n \sum_{j=1}^n x_j y_j - \left(\sum_{j=1}^n x_j\right) \left(\sum_{j=1}^n y_j\right)}{\sqrt{\left(n \sum_{j=1}^n x_j^2 - \left(\sum_{j=1}^n x_j\right)^2\right) \left(n \sum_{j=1}^n y_j^2 - \left(\sum_{j=1}^n y_j\right)^2\right)}} = \varrho(\text{Emp}(\mathbf{x}, \mathbf{y})),$$

$$z_{\mathbf{x}, \mathbf{y}} = \frac{1}{2} \ln \frac{1 + r_{\mathbf{x}, \mathbf{y}}}{1 - r_{\mathbf{x}, \mathbf{y}}} = h(r_{\mathbf{x}, \mathbf{y}}), \quad \text{kde } h(t) = \frac{1}{2} \ln \frac{1+t}{1-t}.$$

Test nekorelovanosti dvou normálních rozdělení,  $H_0: \varrho(X, Y) = 0$ :  $\frac{r_{\mathbf{x}, \mathbf{y}}}{\sqrt{1 - r_{\mathbf{x}, \mathbf{y}}^2}} \sqrt{n-2}$  testujeme na rozdělení

$t(n-2)$ .

Test (nenulové) hodnoty korelace dvou normálních rozdělení,  $H_0: \varrho(X, Y) = c$ , kde  $c \neq 0$ :  $(h(r_{\mathbf{x}, \mathbf{y}}) - h(c)) \sqrt{n-3} = \frac{z_{\mathbf{x}, \mathbf{y}} - \mu_{z_{\mathbf{x}, \mathbf{y}}}}{\sigma_{z_{\mathbf{x}, \mathbf{y}}}}$ , kde  $\mu_{z_{\mathbf{x}, \mathbf{y}}} = h(c) = \frac{1}{2} \ln \frac{1+c}{1-c}$ ,  $\sigma_{z_{\mathbf{x}, \mathbf{y}}} = \sqrt{\frac{1}{n-3}}$ , testujeme na rozdělení  $N(0, 1)$ .

Test rovnosti korelací dvou normálních rozdělení,  $H_0: \varrho(X, Y) = \varrho(U, V)$ :  $\frac{h(r_{\mathbf{x}, \mathbf{y}}) - h(r_{\mathbf{u}, \mathbf{v}})}{\sqrt{\frac{1}{n-3} + \frac{1}{m-3}}} = \frac{z_{\mathbf{x}, \mathbf{y}} - z_{\mathbf{u}, \mathbf{v}}}{\sigma_Z}$ , kde

$$\sigma_Z = \sqrt{\frac{1}{n-3} + \frac{1}{m-3}}, \text{ testujeme na rozdělení } N(0, 1).$$

## 4 Regrese

### 4.1 Lineární model dimenze 1

$$Y = \vartheta_0 + \vartheta_1 X + \mathcal{E}, \quad y_j = \vartheta_0 + \vartheta_1 x_j + e_j.$$

Regresní přímka 1:

$$\begin{aligned} y &= \hat{\vartheta}_0 + \hat{\vartheta}_1 x, \\ \hat{\vartheta}_0 &= \bar{y} - \hat{\vartheta}_1 \bar{x}, \quad \hat{\vartheta}_1 = \frac{y - \bar{y} = \hat{\vartheta}_1 (x - \bar{x})}{\frac{\sum_j x_j y_j - n \bar{x} \bar{y}}{\sum_j x_j^2 - n \bar{x}^2} = \frac{\sum_j (x_j - \bar{x})(y_j - \bar{y})}{\sum_j (x_j - \bar{x})^2}}. \end{aligned}$$

Odhad hodnot nezávisle proměnné v jednotlivých realizacích a chyby (**rezidua**):  $\hat{y}_j = \hat{\vartheta}_0 + \hat{\vartheta}_1 x_j$ ,  $\hat{e}_j = y_j - \hat{y}_j$ .  
Regresní přímka 2:  $x = \hat{\vartheta}_0^* + \hat{\vartheta}_1^* y$ ,  $x - \bar{x} = \hat{\vartheta}_1^* (y - \bar{y})$ .

### 4.2 Interpretace regresních koeficientů

$$\begin{aligned} \hat{\sigma}_x^2 &= \frac{1}{n} \sum_j (x_j - \bar{x})^2 = \text{D Emp}(\mathbf{x}), \\ \hat{\sigma}_y^2 &= \frac{1}{n} \sum_j (y_j - \bar{y})^2 = \text{D Emp}(\mathbf{y}), \\ c_{\mathbf{x}, \mathbf{y}} &= \frac{1}{n} \sum_j (x_j - \bar{x})(y_j - \bar{y}) = \text{cov}(\text{Emp}(\mathbf{x}, \mathbf{y})). \\ r_{\mathbf{x}, \mathbf{y}} &= \frac{c_{\mathbf{x}, \mathbf{y}}}{\hat{\sigma}_x \hat{\sigma}_y}, \quad \hat{\vartheta}_1 = \frac{c_{\mathbf{x}, \mathbf{y}}}{\hat{\sigma}_x^2}, \quad \hat{\vartheta}_1 \hat{\vartheta}_1^* = r_{\mathbf{x}, \mathbf{y}}^2. \end{aligned}$$

$$\text{Regresní přímka 1: } y - \bar{y} = \frac{c_{\mathbf{x}, \mathbf{y}}}{\hat{\sigma}_x^2} (x - \bar{x}), \quad \frac{y - \bar{y}}{\hat{\sigma}_y} = r_{\mathbf{x}, \mathbf{y}} \frac{x - \bar{x}}{\hat{\sigma}_x}.$$

### 4.3 Složky rozptylu regresního odhadu

$$\text{Rozptyl modelu} = \hat{\sigma}_{\hat{\mathbf{y}}}^2 = \frac{1}{n} \sum_j (\hat{y}_j - \bar{\mathbf{y}})^2.$$

$$\text{Reziduální rozptyl} = \hat{\sigma}_{\hat{\mathbf{e}}}^2 = \frac{1}{n} \sum_j \hat{e}_j^2 = \frac{1}{n} \sum_j (y_j - \hat{y}_j)^2.$$

$$\text{Celkový rozptyl} = \hat{\sigma}_{\mathbf{y}}^2 = \frac{1}{n} \sum_j (y_j - \bar{\mathbf{y}})^2 = \hat{\sigma}_{\hat{\mathbf{y}}}^2 + \hat{\sigma}_{\hat{\mathbf{e}}}^2. \quad r_{\mathbf{x}, \mathbf{y}}^2 = \frac{\hat{\sigma}_{\hat{\mathbf{y}}}^2}{\hat{\sigma}_{\mathbf{y}}^2} = 1 - \frac{\hat{\sigma}_{\hat{\mathbf{e}}}^2}{\hat{\sigma}_{\mathbf{y}}^2}.$$

Odhady rozptylu  $\sigma^2$  původního rozdělení:

$$\text{- max. věrohodný: } \hat{\sigma}_{\hat{\mathbf{e}}}^2 = \frac{1}{n} \sum_j \hat{e}_j^2 = \text{D Emp}(\hat{\mathbf{e}}),$$

$$\text{- nestranný: } \hat{\sigma}^2 = \frac{1}{n-2} \sum_j \hat{e}_j^2.$$

### 4.4 Rozdělení odhadů a testy hypotéz o nich

Odhady rozptylů regresních koeficientů:

$$\hat{\sigma}_{\hat{\vartheta}_0}^2 = \frac{\hat{\sigma}_{\hat{\mathbf{e}}}^2}{n^2 \hat{\sigma}_{\mathbf{x}}^2} \sum_j x_j^2 = \frac{\hat{\sigma}_{\hat{\mathbf{e}}}^2}{n(n-2) \hat{\sigma}_{\mathbf{x}}^2} \sum_j x_j^2, \quad \hat{\sigma}_{\hat{\vartheta}_1}^2 = \frac{\hat{\sigma}_{\hat{\mathbf{e}}}^2}{n \hat{\sigma}_{\mathbf{x}}^2} = \frac{\hat{\sigma}_{\hat{\mathbf{e}}}^2}{(n-2) \hat{\sigma}_{\mathbf{x}}^2}.$$

Test absolutního členu,  $H_0: \vartheta_0 = c$ :  $\frac{\hat{\vartheta}_0 - c}{\frac{\hat{\sigma}_{\hat{\mathbf{e}}}^2}{\hat{\sigma}_{\mathbf{x}}^2} \sqrt{\frac{1}{n} \sum_j x_j^2}} \sqrt{n-2}$  testujeme na rozdělení  $t(n-2)$ .

Test směrnice,  $H_0: \vartheta_1 = c$ :  $\frac{\hat{\vartheta}_1 - c}{\frac{\hat{\sigma}_{\hat{\mathbf{e}}}^2}{\hat{\sigma}_{\mathbf{x}}^2}} \sqrt{n-2}$  testujeme na rozdělení  $t(n-2)$ .

Test chyby regrese pro dané  $x$ ,  $H_0: \vartheta_0 + \vartheta_1 x = c$ :  $\frac{\hat{\vartheta}_0 + \hat{\vartheta}_1 x - c}{\hat{\sigma}_{\hat{\mathbf{e}}} \sqrt{n+1 + \frac{n(x-\bar{x})^2}{\hat{\sigma}_{\mathbf{x}}^2}}} \sqrt{n-2}$  testujeme na rozdělení  $t(n-2)$ .

### 4.5 Lineární model dimenze $k$

$$\mathbf{Y} = \sum_{i=1}^k \vartheta_i \mathbf{X}_i + \mathcal{E}, \quad y_j = \sum_{i=1}^k \vartheta_i x_{ji} + e_j, \quad \mathbf{y} = \mathbf{X} \boldsymbol{\vartheta} + \mathbf{e}.$$

Soustava normálních rovnic a její řešení:  $\mathbf{X}^T \mathbf{X} \hat{\boldsymbol{\vartheta}} = \mathbf{X}^T \mathbf{y}$ ,  $\hat{\boldsymbol{\vartheta}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$ .

Kovarianční matice vektoru odhadů  $\hat{\Theta}$ :  $\boldsymbol{\Sigma}_{\hat{\Theta}} = \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1}$ .

**Reziduální součet čtverců:**  $R_{SS} = \sum_{j=1}^n \hat{e}_j^2$ .

$\frac{R_{SS}}{\sigma^2}$  pochází z rozdělení  $\chi^2(n-k)$ .

Odhady rozptylu  $\sigma^2$  původního rozdělení:

$$\text{- maximálně věrohodný: } \hat{\sigma}_{\hat{\mathbf{e}}}^2 = \frac{1}{n} R_{SS} = \frac{1}{n} \sum_{j=1}^n \hat{e}_j^2,$$

$$\text{- nestranný: } \hat{\sigma}^2 = \frac{1}{n-k} R_{SS} = \frac{1}{n-k} \sum_{j=1}^n \hat{e}_j^2.$$

### 4.6 Intervalové odhady regresních koeficientů

$c_{ii} = i$ -tý prvek na diagonále matice  $\mathbf{C} = (\mathbf{X}^T \mathbf{X})^{-1}$ .

Intervalový odhad regresních koeficientů při **známém** rozptylu  $\sigma^2$ :  $\hat{\vartheta}_i \pm \Phi^{-1} \left(1 - \frac{\alpha}{2}\right) \sigma \sqrt{c_{ii}}$ .

Intervalový odhad regresních koeficientů při **neznámém** rozptylu:

$$\hat{\vartheta}_i \pm q_{t(n-k)} \left(1 - \frac{\alpha}{2}\right) \hat{\sigma} \sqrt{c_{ii}} = \hat{\vartheta}_i \pm q_{t(n-k)} \left(1 - \frac{\alpha}{2}\right) \cdot \sqrt{\frac{R_{SS} c_{ii}}{n-k}}.$$

## 5 $\chi^2$ testy

Test dobré shody pozorovaného rozdělení s předpokládaným diskrétním rozdělením:  $\sum_{i=1}^k \frac{(n_i - np_i)^2}{np_i}$   
testujeme na rozdělení  $\chi^2(k-1)$ .

Test dobré shody 2 diskrétních rozdělení:  $\left(\frac{1}{m} + \frac{1}{n}\right) \sum_{i=1}^k \frac{(m_i - mp_i)^2}{mp_i}$ , kde  $p_i = \frac{m_i + n_i}{m+n}$ , testujeme  
na rozdělení  $\chi^2(k-1)$ .

Test nezávislosti 2 diskrétních rozdělení:  $\sum_{i=1}^k \sum_{j=1}^m \frac{(n_{ij} - np_i q_j)^2}{np_i q_j}$ , kde  $p_i = \frac{1}{n} \sum_{j=1}^m n_{ij}$  a  $q_j = \frac{1}{n} \sum_{i=1}^k n_{ij}$ ,  
testujeme na rozdělení  $\chi^2((k-1)(m-1))$ .